



Применение методов машинного обучения при проектировании камер сгорания газотурбинных двигателей

© 2025, Д.С. Борисов¹, К.К. Симовин², Д.Р. Юкина¹✉, А.В. Благов¹, И.В. Чечет¹, С.Г. Матвеев¹

¹ Самарский национальный исследовательский университет имени академика С.П. Королева (Самарский университет), Самара, Россия

² Университет ИТМО, Санкт-Петербург, Россия

Аннотация

В статье рассматривается применение рекуррентной нейронной сети с долгой краткосрочной памятью и алгоритма градиентного бустинга для определения основных геометрических размеров диффузора камеры сгорания авиационного газотурбинного двигателя. Выполнено численное моделирование физических процессов в диффузоре на основе метода конечных элементов и расчёт потерь полного давления. Сформирована база данных геометрических параметров рассматриваемой модели диффузора и соответствующих им результатов расчёта потерь полного давления. Вариант с минимальными потерями полного давления использован в качестве эталона. Проведено сравнение метода градиентного бустинга и нейронной сети с долгой краткосрочной памятью на данных о потерях полного давления, полученных в результате численного моделирования диффузора с различными значениями его геометрических размеров. Погрешность метода градиентного бустинга составила 1,64%, для рекуррентной нейронной сети с долгой краткосрочной памятью – 7,28%. Применённый подход позволяет формировать базу данных вариантов конструкций диффузоров, результаты расчётов использовать для обучения нейронных сетей и в дальнейшем дообучать модели на других конструкциях для использования полученного результата при проектировании камер сгорания.

Ключевые слова: машинное обучение, градиентный бустинг, рекуррентная нейронная сеть, проектирование, диффузор камеры сгорания, метод конечных элементов.

Цитирование: Борисов Д.С., Симовин К.К., Юкина Д.Р., Благов А.В., Чечет И.В., Матвеев С.Г. Применение методов машинного обучения при проектировании камер сгорания газотурбинных двигателей. *Онтология проектирования*. 2025. Т.15. №3(57). С.351-362. DOI: 10.18287/2223-9537-2025-15-3-351-362.

Вклад авторов: Борисов Д.С. – выбор методов машинного обучения и моделей нейронных сетей; Симовин К.К. – подготовка данных, построение и апробация нейросетевых моделей; Юкина Д.Р. – подготовка модели, сбор и систематизация данных; Благов А.В. – постановка задачи, анализ результатов обучения нейросетей; Чечет И.В. – параметризация модели, анализ результатов моделирования и машинного обучения; Матвеев С.Г. – разработка структуры и редактирование статьи.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Введение

Задачи проектирования элементов, узлов и конструкций авиационных двигателей решаются с использованием методов вычислительной газодинамики, специализированных программных комплексов (*Ansys Fluent*¹, *STAR-CCM+*², *OpenFOAM*³, *FLOW-3D*⁴ и др.) и больших вычислительных ресурсов [1]. К такой задаче можно отнести проектирование элементов

¹ <https://www.ansys.com/>.

² <https://plm.sw.siemens.com/en-US/simcenter/fluids-thermal-simulation/star-ccm/>.

³ <https://www.openfoam.com/>.

⁴ <https://www.flow3d.com/>.

камер сгорания (КС) газотурбинных двигателей (ГТД). Важным требованием к КС ГТД является обеспечение потерь полного давления (ППД), не превышающих значений, установленных техническим заданием на проектирование КС [2, 3]. Примерно две трети ППД в КС обусловлены процессами горения и смешения. Остальные потери приходятся на диффузор, который обеспечивает торможение потока воздуха, выходящего из компрессора и его распределение по кольцевым каналам КС. Снижение ППД в диффузоре улучшает характеристики КС и повышает эффективность двигателя в целом [2-5].

Первичный облик КС определяется выбранным прототипом. Проектировочный расчёт прототипа КС позволяет установить: габариты диффузора, геометрию фронтального устройства, объём и габариты жаровой трубы, длину газосборника и т.д. Упрощённая геометрическая модель КС используется для трёхмерного моделирования процессов средствами вычислительной гидродинамики (*Computational Fluid Dynamics, CFD*) [1]. В результате итеративного процесса *CFD*-расчётов получается окончательный вариант проекта конструкции.

Целью данной работы является попытка применения методов интеллектуального анализа данных (ИАД) [6-10] к проектированию проточной части диффузора КС ГТД. В практике проектирования КС используется специализированное программное средство «*Optimization*» в *Ansys*¹, с помощью которого определяют геометрию диффузора, обеспечивающую минимальные ППД и его распределение по каналам КС. Время поиска решения может составлять от нескольких дней до нескольких недель. В результате создаётся большой объём данных, который можно использовать для обучения нейронной сети (НС). Предиктивная аналитика, базирующаяся на использовании нейросетевых моделей, способна быстро и точно прогнозировать различные результаты и явления. Количество и структура данных, по которым проходит обучение моделей, оказывает существенное влияние на их прогностическую способность. Например, недостаточное количество данных влияет на качество и точность прогноза, а увеличение количества данных позволит повысить точность, но может привести к переобучению [11].

1 Выбор методов машинного обучения

Предиктивная аналитика объединяет методы ИАД и прогнозного моделирования с целью прогнозирования будущих событий [6]. Она представляет собой набор инструментов, включающий методы анализа больших данных и статистические методы. Использование различных алгоритмов ИАД позволяет обнаруживать скрытые закономерности, выявлять неизвестные зависимости и обучаться [7].

На начальных этапах ИАД выполняют подготовку и преобразование данных [7, 12]. Частью преобразования является очистка данных, в процессе которой устраняются дубликаты, многозначность, аномалии, пропущенные значения и т.п. Одним из распространённых алгоритмов преобразования является *нормализация* [13]. Другим важным алгоритмом преобразования является *обобщение*, позволяющее объединить данные в категории для более глубокого понимания зависимостей [14].

Перед обучением нейросетевой модели данные необходимо *разделить на выборки* [13]. Обычно используются два типа выборок: контрольная и тренировочная. На контрольную выборку отводится 20%, на тренировочную 80%. Тренировочная выборка разделяется ещё на две: 70% – обучающая и 30% – тестовая выборки. Обучающая выборка используется для обучения модели, тестовая – для оценки её качества, а контрольная – для выбора наилучшей модели.

Следующим этапом определяется тип задачи, решаемой ИАД. Среди основных задач: регрессия, классификация и кластеризация [15]. После этого данные могут обрабатываться посредством построения моделей, онтологических конструкций и других методов. В данной работе применены рекуррентная НС (РНС) с долгой краткосрочной памятью (*Long Short-Term Memory, LSTM*), способная обучаться долгосрочным зависимостям [16], и алгоритм машинного обучения с применением градиентного бустинга над деревьями решений (*Categorical Boosting, CatBoost*) [17].

РНС с долгой краткосрочной памятью способна хранить информацию на протяжении продолжительного времени. На рисунке 1 представлена схема искусственной НС, которая состоит из трёх типов слоёв [18]:

- входной – получает данные;

- скрытый – обрабатывает информацию и может состоять из нескольких скрытых слоёв, количество которых зависит от сложности задачи;
- выходной – генерирует результат.

Каждый нейрон, называемый также сумматором, получает входные сигналы с весами, отражающими их значимость [19]. Нейрон суммирует входные сигналы, умножая их на соответствующие веса. РНС представляют собой последовательность одинаковых сетей, позволяющих запоминать и передавать информацию [20]. Схема работы РНС приведена на рисунке 2.

РНС демонстрируют высокую эффективность при решении задач многомерного прогнозирования и моделирования нелинейных взаимосвязей и не требуют большого количества данных, как глубокие НС [21].

РНС имеют ограниченную способность запоминать информацию на протяжении длительных периодов. Поэтому применяется архитектура *LSTM*, которая позволяет НС хранить и обрабатывать информацию в течение длительного времени. *LSTM*-сети сохраняют состояние ячейки, содержащее информацию, необходимую для запоминания. Управление доступом к информации, хранящейся в состоянии ячейки, осуществляется посредством фильтров, включающих сигмоидальный слой [21]. Схематическое представление архитектуры *LSTM* приведено на рисунке 3.





Рисунок 1 – Схема модели искусственной нейронной сети



U — матрица весов для входных данных; V — матрица весов для выходных данных; W — матрица весов для рекуррентных входных данных; x_t — входное значение в момент времени t ; y_t — выходное значение в момент времени t ; h_t — вектор результата активации скрытых нейронов в момент времени t

Рисунок 2 – Схема рекуррентной нейронной сети




Рисунок 3 – Схема нейронной сети с долгой краткосрочной памятью

В условиях ограниченного объема обучающей выборки целесообразно использовать алгоритмы машинного обучения с применением градиентного бустинга. Градиентный бустинг отличается устойчивостью при недостаточном объеме данных и эффективностью работы с табличными данными. В качестве входных данных принимаются множества X , Y и используется пространство вещественных чисел в качестве оценок. Описать принцип градиентного бустинга можно следующей формулой [22]: $a(x) = C(b(x))$, где $b: X \rightarrow R$ – алгоритмический оператор (базовый алгоритм), а функция $C: R \rightarrow Y$ называется решающим правилом.

Схема алгоритм градиентного бустинга представлена на рисунке 4. В отличие от НС алгоритм градиентного бустинга может обрабатывать данные разных типов. Он применим для прогнозирования числовых значений (регрессия) и для классификации объектов. *CatBoost* эффективно обрабатывает нелинейные зависимости в дан-

ных, а применение $L2$ -регуляризации, осуществляющей штрафование больших весов модели, способствует улучшению обобщающей способности алгоритма [23]:

$$L2 = \lambda \sum_{i=1}^n w_i^2,$$

где λ – коэффициент регуляризации, n – количество элементов в векторе весов, w_i – i -тый элемент вектора весов.

Оценка качества построенной модели осуществляется посредством анализа метрик, релевантных решаемой задаче. Для задач классификации применяется метрика точности, а для задач регрессии – среднеквадратичная ошибка (*Mean Squared Error, MSE*). Другим методом оценки является кросс-валидация, в частности, метод *k-Fold* [13], который включает разделение исходного набора данных на k непересекающихся частей (фолдов). В ходе k итераций каждый из k фолдов поочередно используется в качестве тестовой выборки, а оставшиеся $k-1$ фолды – в качестве обучающей выборки. По завершении k итераций формируется k оценок качества, усреднённое значение которых характеризует общую эффективность модели.




Рисунок 4 – Схема алгоритма градиентного бустинга

2 Задача проектирования диффузора камеры сгорания ГТД

Уровень ППД современных КС лежит в диапазоне 4,5-6,5% и определяется по формуле:

$$\Delta p^* = \frac{P_{\text{вх}}^* - P_{\text{вых}}^*}{P_{\text{вх}}^*} 100\%, \quad (1)$$


где $P_{\text{вх}}^*$ – полное давление на входе в диффузор; $P_{\text{вых}}^*$ – полное давление на выходе из КС.

Около 3-3,5% ППД возникают в процессах смесеобразования, горения и смешения в жаровой трубе КС, 1-3% – при торможении потока воздуха, выходящего из компрессора, и его распределении по кольцевым каналам КС [2, 3].

Объектом исследования является диффузор КС с внезапным расширением, схема которого представлена на рисунке 5. Для трёхмерного *CFD*-расчёта рассмотрен сектор диффузора (10°) кольцевой КС. В процессе расчёта положения входного и выходного сечений и их размеры оставались неизменными. Элементы внутреннего и внешнего корпусов приняты линейными для упрощения автоматического построения конечно-элементной модели (КЭМ). Геометрия диффузора определена следующими параметрами: L_d – длина диффузора, d_d – диаметр до точки пересечения линии угла нацеливания α с выходным сечением диффузора, α_1 и α_2 – углы раскрытия стенок диффузора.

Линейные и угловые размеры варьировались в диапазонах, основанных на экспериментальных данных, включённых в методики одномерного проектирования [3, 24, 25]: угол раскрытия диффузора $9^\circ \dots 11^\circ$; $L_d = 63 \dots 77$ мм; $d_d = 456 \dots 558$ мм.

Для *CFD*-расчёта создана КЭМ с максимальным размером элемента 1,2 мм и минимальным 0,15 мм. Количество элементов в модели во всех вариантах расчёта составило около 200 тыс. элементов. Ортогональное качество элементов модели 0,2.



1 – диффузор, 2 – элементы корпуса

Рисунок 5 – Схема конструкции диффузора КС с внезапным расширением

Расчёты выполнялись для значений давления на входе в КС в диапазоне 3,2- 5,2 МПа, что соответствовало режимам работы ГТД во время взлёта и посадки.

Выполнены расчёты 2142 вариантов геометрии диффузора. На каждом шаге автоматического расчёта записывались значения всех геометрических параметров диффузора, давления на выходе и рассчитывались ППД. Минимальное значение ППД принято за эталон. На полученных значениях обучены нейросетевая модель и алгоритм градиентного бустинга. Результаты прогнозов верифицированы по *CFD*-расчёту.

Для сравнения потерь, предсказанных методами РНС и *CatBoost*, и потерь, полученных в результате *CFD*-расчёта, определена относительная погрешность

$$\delta = \frac{|\Delta p^*_{predicted} - \Delta p^*_{CFD}|}{\Delta p^*_{CFD}} 100\%, \quad (2)$$

где $\Delta p^*_{predicted}$ – предсказанные ППД; Δp^*_{CFD} – ППД, полученный в результате *CFD*-расчёта.

3 Реализация методов *LSTM* и *CatBoost*

Для реализации методов *LSTM* и *CatBoost* на *Python* использовались данные, полученные при трёхмерном численном моделировании диффузора. Набор данных содержит восемь столбцов значений: входное и выходное давления, процент потерь и пять геометрических параметров диффузора. После предварительной обработки данных (2142 варианта), включающей удаление дубликатов и строк с пропущенными значениями, он был сокращён до 1720. Нормализация данных выполнена тремя методами: минимума-максимума; Z-масштабирования; на основе среднего значения [26]. Данные были разделены на обучающую, тестовую и контрольную выборки и преобразованы в формат, совместимый с используемыми методами машинного обучения.

Для построения и оценки моделей *LSTM* использовался фреймворк *Keras* [27]. Архитектура модели включала входной слой, заданное количество скрытых слоёв и выходной слой, оптимизированный с помощью алгоритма *Adam* [28]. Перебор гиперпараметров, включая точность обучения, размер пакета данных, тип нормализации и количество скрытых слоёв, проводился с использованием кросс-валидации и отрицательной среднеквадратичной ошибки в качестве функции потерь. Обучение модели осуществлялось с использованием лучших параметров, определённых в процессе перебора, и последующим восстановлением исходных значений для оценки результатов.

Для оценки влияния предобработки данных на эффективность алгоритма градиентного бустинга деревья решений были протестированы на данных с различными типами нормализации, а также на исходном, ненормализованном наборе данных. С целью оптимизации гиперпараметров каждой модели *CatBoost* (обученной на данных с различными типами нормализации) был реализован поиск по сетке с варьированием скорости обучения, глубины дерева, количества итераций и коэффициента *L2*-регуляризации. Оценка качества моделей производилась посредством кросс-валидации с использованием *MultiRMSE* [17]:

$$MultiRMSE = \sqrt{\sum_{i=1}^N \sum_{d=1}^{dim} (y_{id} - \hat{y}_{id})^2},$$

где N — количество наблюдений в выборке; dim — количество зависимых переменных; y_{id} — истинное значение d -го признака для i -го наблюдения; $\hat{y}_{id}$ — предсказанное моделью значение d -го признака для i -го наблюдения.

Перед проведением вычислительного эксперимента выполняется настройка моделей. Из набора данных выделена тестовая выборка, на которой методом *grid search* [29] определены гиперпараметры моделей: тип нормализации данных; количество скрытых слоёв; размеры

пакетов данных; количество итераций; коэффициенты регуляризации; глубина и точность обучения. Гиперпараметры для методов *LSTM* и *CatBoost* представлены в таблице 1. Тип нормализация для метода *LSTM* был выбран максимально-минимальный, точность обучения составила 0,001, а для метода *CatBoost* – 0,1. Схемы моделей, применённые для каждого метода, представлены на рисунках 6-8.

Таблица 1 – Гиперпараметры методов *LSTM* и *CatBoost*

Метод	<i>LSTM</i>		<i>CatBoost</i>		
Гиперпараметры	Количество скрытых слоев	Размер пакета данных	Количество итераций	Коэффициент регуляризации	Глубина
По проценту потерь	5	1	1000	5	4
По углам	3	1	3000	7	10
По линейным параметрам	5	15	3000	7	15




Рисунок 6 – Схема модели, предиктором которой является потеря полного давления в диффузоре




Рисунок 7 – Схема модели, предикторами которой являются углы раскрытия диффузора и наклона осевой линии




Рисунок 8 – Схема модели, предикторами которой являются линейные параметры диффузора

4 Вычислительный эксперимент и анализ результатов

В ходе вычислительного эксперимента верифицировались значения ППД, предсказанные методами *LSTM* и *CatBoost* со значениями ППД, полученными в результате численного моделирования диффузора в *Ansys Fluent*. Модель диффузора строилась по спрогнозированным геометрическим параметрам. Значения входных параметров для каждой модели задавались случайным образом из принятых диапазонов (см. раздел 2). В модели, предиктором которой был процент ППД, задаваемый диапазон ограничен максимальным значением 1,1%.

В таблице 2 представлены примеры трёх строк из набора данных, полученного в результате расчётов в *Ansys Fluent*. Входные параметры для моделей *LSTM* и *CatBoost* брались из этих строк, выходные – предсказывались. По ним строилась геометрия диффузора и проводился верификационный расчёт прогноза по моделям *LSTM* и *CatBoost*.

Вычислительный эксперимент повторен 12 раз. Определены погрешности спрогнозированных процентов ППД от эталонных, полученных в результате расчётов в *Ansys Fluent*. Построены графики зависимости погрешности от спрогнозированного процента потерь (рисунки 9 и 10). Для каждой модели определено среднее значение погрешности предсказанных ППД. Метод *CatBoost* обеспечивает наилучшую точность предсказания геометрических параметров диффузора по проценту потерь (средняя погрешность 1,64%). Сводные данные приведены в таблице 3.

Таблица 2 – Полученные параметры диффузора с помощью разных алгоритмов на трёх наборах предикторов

Методы	Набор X	L_D , мм	d_D , мм	α , град	α_1 , град	α_2 , град	$P_{ВЫХ}^*$, МПа	$P_{ВН}^*$, МПа	Δp^* , %
Ansys	По проценту потерь	72,69	466,26	2,39	5,80	6,10	5,230	5,249	0,36
	По углам	77,70	522,00	2,50	4,57	5,77	3,179	3,205	0,80
	По линейным параметрам	75,00	542,00	1,50	3,60	5,40	3,183	3,205	0,66
CatBoost	По проценту потерь	73,20	468,80	2,30	6,10	6,20	5,230	5,249	0,36
	По углам	77,20	538,40	2,50	4,57	5,77	3,176	3,205	0,90
	По линейным параметрам	75,00	542,00	1,90	4,50	5,80	3,186	3,205	0,56
Верификация прогноза CatBoost	По проценту потерь	73,20	468,80	2,30	6,10	6,20	5,227	5,249	0,37
	По углам	77,20	538,40	2,50	4,57	5,77	3,175	3,205	0,93
	По линейным параметрам	75,00	542,00	1,90	4,50	5,80	3,186	3,205	0,58
LSTM	По проценту потерь	79,00	453,60	2,74	6,64	6,90	3,190	3,202	0,36
	По углам	79,67	491,08	2,50	4,57	5,77	4,587	4,641	1,17
	По линейным параметрам	75,00	542,00	2,50	4,57	5,77	4,458	4,508	1,12
Верификация прогноза LSTM	По проценту потерь	79,00	453,60	2,74	6,64	6,90	3,190	3,202	0,38
	По углам	79,67	491,08	2,50	4,57	5,77	4,580	4,641	1,30
	По линейным параметрам	75,00	542,00	2,50	4,57	5,77	4,450	4,509	1,29




Рисунок 9 – Зависимости погрешности моделей CatBoost, среднее значение погрешности модели (пунктирная линия)




Рисунок 10 – Зависимости погрешности моделей LSTM, среднее значение погрешности модели (пунктирная линия)

Таблица 3 – Средние значения погрешностей методов

Методы	Модели		
	По потерям, $X=\Delta p^*$	По углам, $X=\{\alpha, \alpha_1, \alpha_2\}$	По линейным параметрам $X=\{L_D, d_D\}$
CatBoost	1,64%	3,11%	2,84%
LSTM	7,28%	11,39%	12,19%

Для взаимодействия с обученными моделями создан веб-интерфейс с использованием следующих технологий.

- *React*⁵: библиотека *JavaScript*, обеспечивающая динамическое обновление пользовательского интерфейса.
- *Material UI (MUI)*⁶: библиотека готовых компонентов пользовательского интерфейса.
- *React-hot-toast*⁷: инструмент для визуализации.
- *Flask*⁸: фреймворк для разработки серверной части системы.

⁵ <https://react.dev/>

⁶ <https://mui.com/material-ui/>

⁷ <https://react-hot-toast.com/>

⁸ <https://flask.palletsprojects.com/en/stable/>

Заключение

В работе проведено сравнение вариантов применения методов, использующих нейросетевую *LSTM* модель и алгоритм градиентного бустинга *CatBoost*, для проектирования диффузора КС ГТД. Анализ полученных результатов показал, что *CatBoost* предпочтителен при имеющемся объеме обучающих данных. Средняя погрешность *CatBoost* составила 1,64%.


Формирование базы данных, полученных с помощью *CFD*-расчётов, позволило на основе машинного обучения существенно сократить время предварительной оценки геометрических параметров диффузора КС ГТД.

Список источников

- [1] *Papkov V., Shadymov N., Pashchenko D.* CFD-modeling of fluid flow in Ansys Fluent using Python-based code for automation of repeating calculations. *International Journal of Modern Physics C*. 2023. Vol.34. Iss.09. P.1-15. DOI: 10.1142/S0129183123501140.
- [2] *Лефевр А.* Процессы в камерах сгорания ГТД. М.: Мир. 1986. 566 с.
- [3] *Григорьев А.В., Митрофанов В.А., Рудаков О.А., Саливон Н.Д.* Теория камеры сгорания. Под ред. О.А. Рудакова. Санкт-Петербург: Наука. 2010. 227 с.
- [4] *Ланский А.М., Лукачев С.В., Матвеев С.Г.* Формы, режимы течения и критерии эффективности диффузоров камер сгорания малоразмерных газотурбинных двигателей. *Научный вестник МГТУ ГА*. 2013. Т.197. С.16-19.
- [5] *Ланский А.М., Лукачев С.В., Матвеев С.Г.* Рабочий процесс камер сгорания малоразмерных ГТД. Самара: Изд-во СамНЦ РАН. 2016. 260 с.
- [6] *Klimberg R.* Fundamentals of Predictive Analytics with JMP, Third Edition. *SAS Institute*. 2023. 494 p.
- [7] *Chen M.-S., Han J., Yu P.S.* Data mining: an overview from a database perspective. *IEEE Transactions on Knowledge and Data Engineering*. 1996. Vol.8. Iss.6. P.866–883. DOI: 10.1109/69.553155.
- [8] *Ghahramani M., Qiao Y., Zhou M.C., O'Hagan A., Sweeney J.* AI-based modeling and data-driven evaluation for smart manufacturing processes. *IEEE/CAA Journal of Automatica Sinica*. 2020. Vol.7. Iss.4. P.1026–1037. DOI: 10.1109/jas.2020.1003114.
- [9] *Voulodimos A., Doulamis N., Doulamis A., Protopapadakis E.* Deep Learning for Computer Vision: a Brief Review. *Computational Intelligence and Neuroscience*. 2018. Vol.2018. P.1–13. DOI: 10.1155/2018/7068349.
- [10] *Gareev A., Protsenko V., Stadnik D., Greshniakov P., Yuzifovich Yu., Minaev E., Gimadiev A., Nikonorov A.* Improved Fault Diagnosis in Hydraulic Systems with Gated Convolutional Autoencoder and Partially Simulated Data. *Sensors. Multidisciplinary Digital Publishing Institute*. 2021. Vol.21. Iss.13. P.4410. DOI: 10.3390/s21134410.
- [11] *Goodfellow I., Bengio Y., Courville A.* Deep Learning. *Cambridge, Massachusetts: The MIT Press*. 2016. 781 p.
- [12] *Kusiak A.* Feature transformation methods in data mining. *IEEE Transactions on Electronics Packaging Manufacturing*. 2001. Vol.24. Iss.3. P.214–221. DOI: 10.1109/6104.956807.
- [13] *Xu Y., Goodacre R.* On Splitting Training and Validation Set: A Comparative Study of Cross-Validation, Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning. *Journal of Analysis and Testing*. 2018. Vol.2. Iss.3. P.249–262. DOI: 10.1007/s41664-018-0068-2.
- [14] *Zhou K., Liu Z., Qiao Y., Xiang T., Loy C.C.* Domain Generalization: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2022. Vol.45. Iss.4. P.4396–4415. DOI: 10.1109/tpami.2022.3195549.
- [15] *Bzdok D., Altman N., Krzywinski M.* Statistics versus machine learning. *Nature Methods*. 2018. Vol.15. Iss.4. P.233-234. DOI: 10.1038/nmeth.4642.
- [16] *Hochreiter S., Schmidhuber J.* Long short-term memory. *Neural Computation*. 1997. Vol.9. Iss.8. P.1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
- [17] *Dorogush A.V., Ershov V., Gulin A.* CatBoost: gradient boosting with categorical features support. *arXiv.org*. 2018. 7 p. DOI: 10.48550/arXiv.1810.11363
- [18] *Ryskova D., Nikonorov A., Pirogov A., Makarov A., Skidanov R., Muzyka A., Podlipnov V., Firsov N., Ivliev N., Lobanov V.* Neural network classification of soils with different carbon and calcium content based on hyperspectral data. *2023 IX International Conference on Information Technology and Nanotechnology (ITNT)*. IEEE, 2023. P.1–4. DOI: 10.1109/itnt57377.2023.10139139.
- [19] *Wu Y., Feng J.* Development and Application of Artificial Neural Network. *Wireless Personal Communications*. 2017. Vol.102. P.1645–1656. DOI: 10.1007/s11277-017-5224-x.
- [20] *Sharkawy A.-N.* Principle of Neural Network and Its Main Types: Review. *Journal of Advances in Applied & Computational Mathematics*. 2020. Vol.7. Iss.1. P.8–19. DOI: 10.15377/2409-5761.2020.07.2.

- [21] **Yu Y., Si X., Hu C., Zhang J.** A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation*. 2019. Vol.31. Iss.7. P.1235–1270. DOI: 10.1162/neco_a_01199.
- [22] **Арзамасцев С.А., Бгатов М.В., Картышева Е.Н., Деркунский В.А., Семенчиков Д.Н.** Предсказание оттока абонентов: сравнение методов машинного обучения. *Computer Tools in Education*. 2018. Т.5. С.5–23. DOI: 10.32603/2071-2340-2018-5-5-23.
- [23] **Bühlmann P., Yu B.** Boosting. *WIREs Computational Statistics*. 2009. Vol.2. Iss.1. P.69–74. DOI: 10.1002/wics.55.
- [24] **Гриценко Е. А., Данильченко В. П., Лукачев С. В., Ковылов Ю. Л., Резник В. Е., Цыбизов Ю. И.** Некоторые вопросы проектирования авиационных газотурбинных двигателей. Самара: СНЦ РАН. 2002. 527 с.
- [25] **Давлетшин Ф.М., Овчинников А.А., Николаев Н.А.** Интенсификация теплообмена при дисперсно-кольцевом течении газожидкостного потока в каналах. Казань: КФУ. 2001. С.87.
- [26] **Старовойтов В.В., Голуб Ю.И.** Нормализация данных в машинном обучении. *Информатика*. 2021. Т.18(3). С.83–96. DOI: 10.37661/1816-0301-2021-18-3-83-96.
- [27] **John J., Nonsiri S., Monsakul A.** Keras and TensorFlow: A Hands-On Experience. *Advanced Deep Learning for Engineers and Scientists*. 2021. Vol.4. P.85–111. DOI: 10.1007/978-3-030-66519-7-4.
- [28] **Kingma D., Ba J.** Adam: A Method for Stochastic Optimization. *Computer Science*. 2014. P.15. DOI: 10.48550/arXiv.1412.6980.
- [29] **Syarif I., Prugel-Bennett A., Wills G.** SVM Parameter Optimization Using Grid Search and Genetic Algorithm Improve Classification. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*. 2016. Vol.14. Iss.4. P.1502-1509. DOI: 10.12928/TELKOMNIKA.v14i4.3956.

Сведения об авторах



Борисов Дмитрий Сергеевич, 1999 г. рождения. Аспирант кафедры технической кибернетики Самарского университета. Область научных интересов сосредоточена на разработке программных средств для интеллектуального анализа данных. Author ID (Scopus): 57202978154, Author ID (ORCID): 0009-0007-5315-2357. dimaborisov290699@yandex.ru.

Симовин Кирилл Константинович, 2003 г. рождения. Окончил Самарский университет (2024). Студент магистратуры ИТМО. Author ID (РИНЦ): 1275296, Author ID (ORCID): 0009-0005-3928-7218. ksimovin@bk.ru.



Благов Александр Владимирович, 1985 г. рождения. Окончил Самарский государственный аэрокосмический университет имени академика С.П. Королева в 2008 г., к.т.н. (2011), доцент (2023). Доцент кафедры технической кибернетики Самарского университета. Область научных интересов: интеллектуальный анализ, кластеризация и классификация данных. Author ID (Scopus): 56641501400, Author ID (РИНЦ): 623124. blagov@ssau.ru.

Юкина Дарья Романовна, 2000 г. рождения. Аспирант кафедры теплотехники и тепловых двигателей Самарского университета. Область научных интересов: рабочие процессы в камерах сгорания ГТД. Author ID (РИНЦ): 1261698, Author ID (ORCID): 0009-0001-2478-9646. bobkova.dr@ssau.ru. ✉.



Чет Иван Викторович, 1975 г. рождения. Окончил аспирантуру Самарского государственного аэрокосмического университета имени академика С.П. Королева в 2000 г., к.т.н. (2018). Доцент кафедры теплотехники и тепловых двигателей Самарского университета. Область научных интересов: рабочие процессы в камерах сгорания ГТД. Author ID (Scopus): 57057784900, Author ID (РИНЦ): 590961. Author ID (ORCID): 0000-0002-0439-1921. chechet@ssau.ru.

Матвеев Сергей Геннадьевич, 1959 г. рождения. Окончил Куйбышевский авиационный институт имени академика С.П. Королева в 1982 г., к.т.н. (1989), доцент (2002). Профессор кафедры теплотехники и тепловых двигателей Самарского университета. Область научных интересов: рабочие процессы в камерах сгорания ГТД. Author ID (Scopus): 7005054165, Author ID (ORCID): 0000-0002-2865-241X, Author ID (РИНЦ): 379745. msg@ssau.ru.



Поступила в редакцию 23.01.2025, после рецензирования 27.06.2025. Принята к публикации 01.07.2025.



Application of machine learning methods in designing combustion chambers of gas turbine engines

© 2025, D.S. Borisov¹, K.K. Simovin², D.R. Yukina¹✉, A.V. Blagov¹, I.V. Chechet¹, S.G. Matveev¹

¹ Samara National Research University named after Academician S.P. Korolev, Samara, Russia

² ITMO University, St. Petersburg, Russia

Abstract

The article considers the application of a recurrent neural network with long short-term memory (LSTM) and a gradient boosting algorithm for determining the key geometric dimensions of the diffuser of the combustion chamber of an aircraft gas turbine engine. Numerical modeling of physical processes in the diffuser is performed based on the finite element method, and total pressure losses are subsequently calculated. A database is compiled containing various geometric configurations of the diffuser model alongside the corresponding total pressure loss values. The configuration with the lowest total pressure loss is selected as the reference. The performance of the gradient boosting method is compared with that of the LSTM neural network, based on the total pressure loss data obtained from numerical modeling of the diffuser across a range of geometric configurations. The gradient boosting approach yielded an error of 1.64%, whereas the LSTM network demonstrated an error of 7.28%. This approach enables the creation of a design database for diffuser configurations, facilitates the use of simulation data to train neural networks, and allows for subsequent training on alternative designs. The results can be applied in the design and optimization of combustion chambers in aircraft engines.

Keywords: machine learning, gradient boosting, recurrent neural network, designing, combustion chamber diffuser, finite element method.

For citation: Borisov D.S., Simovin K.K., Yukina D.R., Blagov A.V., Chechet I.V., Matveev S.G. Application of machine learning methods in designing combustion chambers of gas turbine engines [In Russian]. *Ontology of designing*. 2025; 15(3): 351-362. DOI: 10.18287/2223-9537-2025-15-3-351-362.

Authors' contributions: Borisov D.S. – selection of machine learning methods and neural network models; Simovin K.K. – data preparation, development and testing of neural network models; Yukina D.R. – model preparation, data collection and systematization; Blagov A.V. – problem statement, analysis of neural network training results; Chechet I.V. – model parameterization, analysis of modeling and machine learning results; Matveev S.G. – development of the article structure and editorial revision.

Conflict of interest: The authors declare no conflict of interest.

List of figures and tables

- Figure 1 – Diagram of the artificial neural network model
- Figure 2 – Diagram of the recurrent neural network
- Figure 3 – Diagram of the long short-term memory (LSTM) neural network
- Figure 4 – Diagram of the gradient boosting algorithm
- Figure 5 – Diagram of the diffuser design of the combustion chamber with sudden expansion
- Figure 6 – Diagram of the model with total pressure loss in the diffuser as the predictor
- Figure 7 – Diagram of the model with the diffuser expansion angles and the axial line inclination as predictors
- Figure 8 – Diagram of the model with the diffuser linear parameters as predictors
- Figure 9 – Graph of the error dependence of CatBoost models, average model error (dashed line)
- Figure 10 – Graph of the error dependence of LSTM models, average model error (dashed line)
- Table 1 - Hyperparameters of LSTM and CatBoost methods
- Table 2 - Diffuser parameters obtained using different algorithms on three sets of predictors
- Table 3 - Average error values of the methods (in percent)

References

- [1] **Papkov V, Shadymov N, Pashchenko D.** CFD-modeling of fluid flow in Ansys Fluent using Python-based code for automation of repeating calculations. *International Journal of Modern Physics C.* 2023; 34(09): 1-15. DOI: 10.1142/S0129183123501140.
- [2] **Lefevre A.** Gas Turbine Engine Combustion Processes [In Russian]. Moscow: Mir Publ.; 1986. 566 p.
- [3] **Grigoriev AV, Mitrofanov VA, Rudakov OA, Salivon ND.** Combustion Chamber Theory [In Russian]. Ed. by O.A. Rudakov. Saint Petersburg: Nauka; 2010. 227 p.
- [4] **Lansky AM, Lukachev SV, Matveev SG.** Forms, flow modes and efficiency criteria of combustion chamber diffusers of small-size gas turbine engines [In Russian]. *Scientific Bulletin of MSTU GA.* 2013; 197: 16-19.
- [5] **Lansky AM, Lukachev SV, Matveev SG.** Combustion chamber workflow of small-size GTEs [In Russian]. Samara: Publishing of SamNC RAS.; 2016. 260 p.
- [6] **Klimberg R.** Fundamentals of Predictive Analytics with JMP, Third Edition. SAS Institute; 2023. 494 p.
- [7] **Chen MS, Han J, Yu PS.** Data mining: an overview from a database perspective. *IEEE Transactions on Knowledge and Data Engineering.* 1996; 8(6): 866–883. DOI: 10.1109/69.553155.
- [8] **Ghahramani M, Qiao Y, Zhou MC, O'Hagan A, Sweeney J.** AI-based modeling and data-driven evaluation for smart manufacturing processes. *IEEE/CAA Journal of Automatica Sinica.* 2020; 7(4): 1026–1037. DOI: 10.1109/jas.2020.1003114.
- [9] **Voulodimos A, Doulamis N, Doulamis A, Protopapadakis E.** Deep Learning for Computer Vision: a Brief Review. *Computational Intelligence and Neuroscience.* 2018; 2018: 1–13. DOI: 10.1155/2018/7068349.
- [10] **Gareev A, Protsenko V, Stadnik D, Greshniakov P, Yuzifovich Yu, Minaev E, Gimadiev A, Nikonorov A.** Improved Fault Diagnosis in Hydraulic Systems with Gated Convolutional Autoencoder and Partially Simulated Data. *Sensors.* Multidisciplinary Digital Publishing Institute. 2021; 21(13): 4410. DOI: 10.3390/s21134410.
- [11] **Goodfellow I, Bengio Y, Courville A.** Deep Learning. Cambridge, Massachusetts: The MIT Press.; 2016. 781 p.
- [12] **Kusiak A.** Feature transformation methods in data mining. *IEEE Transactions on Electronics Packaging Manufacturing.* 2001; 24(3): 214–221. DOI: 10.1109/6104.956807.
- [13] **Xu Y, Goodacre R.** On Splitting Training and Validation Set: A Comparative Study of Cross-Validation, Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning. *Journal of Analysis and Testing.* 2018; 2(3): 249–262. DOI: 10.1007/s41664-018-0068-2.
- [14] **Zhou K, Liu Z, Qiao Y, Xiang T, Loy CC.** Domain Generalization: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence.* 2022; 45(4): 4396–4415. DOI: 10.1109/tpami.2022.3195549.
- [15] **Bzdok D, Altman N, Krzywinski M.** Statistics versus machine learning. *Nature Methods.* 2018; 15(4): 233-234. DOI: 10.1038/nmeth.4642.
- [16] **Hochreiter S, Schmidhuber J.** Long short-term memory. *Neural Computation.* 1997; 9(8): 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
- [17] **Dorogush AV, Ershov V, Gulin A.** CatBoost: gradient boosting with categorical features support; 2018. 7 p. DOI: 10.48550/arXiv.1810.11363
- [18] **Ryskova D, Nikonorov A, Pirogov A, Makarov A, Skidanov R, Muzyka A, Podlipnov V, Firsov N, Ivliev N, Lobanov V.** Neural network classification of soils with different carbon and calcium content based on hyperspectral data. 2023 IX International Conference on Information Technology and Nanotechnology (ITNT). IEEE. 2023: 1–4. DOI: 10.1109/itnt57377.2023.10139139.
- [19] **Wu Y, Feng J.** Development and Application of Artificial Neural Network. *Wireless Personal Communications.* 2017; 102: 1645–1656. DOI: 10.1007/s11277-017-5224-x.
- [20] **Sharkawy AN.** Principle of Neural Network and Its Main Types: Review. *Journal of Advances in Applied & Computational Mathematics.* 2020; 7(1): 8–19. DOI: 10.15377/2409-5761.2020.07.2.
- [21] **Yu Y, Si X, Hu C, Zhang J.** A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation.* 2019; 31(7): 1235–1270. DOI: 10.1162/neco_a_01199.
- [22] **Arzamastsev SA, Bgatov MV, Kartysheva EN, Derkunsky VA, Semenchikov DN.** Prediction of subscriber churn: comparison of machine learning methods [In Russian]. *Computer Tools in Education.* 2018; 5: 5-23. DOI: 10.32603/2071-2340-2018-5-5-23.
- [23] **Bühlmann P, Yu B.** Boosting. *WIREs Computational Statistics.* 2009; 2(1): 69–74. DOI: 10.1002/wics.55.
- [24] **Gritsenko EA, Danilchenko VP, Lukachev SV, Kovylov YL, Reznik VE, Tsybizov YI.** Some issues of designing aircraft gas turbine engines [In Russian]. Samara: SSC RAS; 2002. 527 p.
- [25] **Davletshin FM, Ovchinnikov AA, Nikolaev NA.** Intensification of heat exchange at dispersed-ring flow of gas-liquid flow in channels [In Russian]. Kazan: Kazan Federal University; 2001. 87 p.
- [26] **Starovoitov VV, Golub YI.** Data Normalization in Machine Learning [In Russian]. *Informatics.* 2021; 18(3): 83–96. DOI: 10.37661/1816-0301-2021-18-3-83-96.

- [27] **John J, Nonsiri S, Monsakul A.** Keras and TensorFlow: A Hands-On Experience. *Advanced Deep Learning for Engineers and Scientists*. 2021; 4: 85–111. DOI: 10.1007/978-3-030-66519-7-4.
 - [28] **Kingma D, Ba J.** Adam: A Method for Stochastic Optimization. *Computer Science*. 2014: 1-15. DOI: 10.48550/arXiv.1412.6980.
 - [29] **Syarif I, Prugel-Bennett A, Wills G.** SVM Parameter Optimization Using Grid Search and Genetic Algorithm Improve Classification. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*. 2016; 14(4): 1502-1509. DOI: 10.12928/TELKOMNIKA.v14i4.3956.
-

About the authors

Dmitry Sergeevich Borisov (b. 1999) is a postgraduate student of the Department of Technical Cybernetics at Samara National Research University named after Academician S.P. Korolev. The research interests include development of software tools for intelligent data analysis. Author ID (Scopus): 57202978154, Author ID (ORCID): 0009-0007-5315-2357. dimaborisov290699@yandex.ru.

Kirill Konstantinovich Simovin (b. 2003) graduated from Samara National Research University named after Academician S.P. Korolev in 2024. A first-year Master's student at ITMO University. Author ID (RSCI): 1275296, Author ID (ORCID): 0009-0005-3928-7218. ksimovin@bk.ru.

Alexander Vladimirovich Blagov (b. 1985) graduated from the Samara State Aerospace University named after Academician S.P. Korolev in 2008, Ph.D. (2011), Associate Professor (2023). He is currently an associate professor of the Department of Technical Cybernetics at Samara National Research University named after Academician S.P. Korolev. His research interests include intelligent analysis, clustering, and data classification. Author ID (Scopus): 56641501400, Author ID (RSCI): 623124. blagov@ssau.ru.

Daria Romanovna Yukina (b. 2000) is a postgraduate student of the Department of Heat Engineering and Heat Engines at Samara National Research University named after Academician S.P. Korolev. Her research interests include operating processes in gas turbine combustion chambers. Author ID (ORCID): 0009-0001-2478-9646, Author ID (RSCI): 1261698. bobkova.dr@ssau.ru. .

Ivan Viktorovich Chechet (b. 1975) graduated from the postgraduate program of the Samara State Aerospace University named after Academician S.P. Korolev in 2000, Ph.D. (2018). He is an associate professor of the Department of Heat Engineering and Heat Engines at Samara National Research University named after Academician S.P. Korolev. The research interests include operating processes in gas turbine engine combustion chambers. Author ID (Scopus): 57057784900, Author ID (ORCID): 0000-0002-0439-1921. Author ID (RSCI): 590961. chechet@ssau.ru.

Sergey Gennadievich Matveev (b. 1959) graduated from the Kuibyshev Aviation Institute named after Academician S.P. Korolev in 1982, Ph.D. (1989), Associate Professor (2002). He is a professor of the Department of Heat Engineering and Heat Engines, Samara National Research University named after Academician S.P. Korolev. His research interests include operating processes in gas turbine engine combustion chambers. Author ID (Scopus): 7005054165, (ORCID): 0000-0002-2865-241X, Author ID (RSCI): 379745. msg@ssau.ru.

Received January 21, 2025. Revised June 27, 2024. Accepted July 01, 2025.
